

DOI: <https://doi.org/10.37162/2618-9631-2024-4-90-108>

УДК 556.536+519.688+004.8+004.438

Метод долгосрочного прогноза максимального уровня воды р. Исеть на основе глубокого обучения

Э.Р. Акмаев, А.В. Романов

*Гидрометеорологический научно-исследовательский центр
Российской Федерации, г. Москва, Россия
alexey.romanov@mecom.ru, akmaew1@gmail.com*

Выполнен численный анализ применимости алгоритмов глубокого обучения при разработке метода долгосрочного прогноза максимального уровня воды для трех гидрологических постов р. Исеть (Катайск, Шадринск, Мехонское). Детально проанализированы возможности реализации двух архитектур исходной нейросетевой модели в рамках использования одного и того же набора исходных гидрометеорологических данных наблюдений. Показано, что переход на новую архитектуру N-HiTS позволяет увеличить оправдываемость прогноза на валидационной выборке по сравнению с ранее использованной архитектурой TFT. С помощью кросс-валидации получены оценки классического статистического критерия эффективности разработанного метода (S/σ), подтверждающие возможность его использования в оперативной практике для всех трёх анализируемых гидрологических постов. В рамках разработанного метода прогноза выполнен анализ учёта данных наблюдений за уровнем грунтовых вод на подземных скважинах системы Роснедра. Показано, что использование таких данных наблюдений позволяет в ряде случаев существенно повысить эффективность метода прогноза.

Ключевые слова: долгосрочные гидрологические прогнозы, половодье, уравнение водного баланса, уравнение регрессии, нейронные сети, уровень воды, водный режим, глубокое машинное обучение

Deep learning long-term method of maximum water level forecast of the Iset

E.R. Akmaev, A.V. Romanov

*Hydrometeorological Research Center of Russian Federation,
Moscow, Russia
alexey.romanov@mecom.ru, akmaew1@gmail.com*

Numerical analysis of using deep learning in the development of long-term method of maximum water level forecast for several gauging stations of the Iset (Kataysk, Shadrinsk, Mekhonskoe) has been carried out. The possibilities of implementing two architectures of neural network model within the framework of using the same set of initial hydrometeorological observation data have been analysed in detail. It is shown that the transition to the new N-HiTS architecture allows increasing the correctness of the forecast on the validation sample in comparison with the previously used TFT architecture. Using cross-validation we obtained estimates of the classical statistical criterion of correctness of the developed method confirming the possibility of its use in operational practice for all three analysed

gauging stations. Within the framework of the developed forecasting method the analysis of groundwater level observation data at groundwater wells of the Rosnedra system was carried out. It is shown that in a number of cases using such observation data allows significantly improve the correctness of forecast.

Keywords: hydrological long-term forecasts, flooding, hydrologic equation, regression equation, neural networks, water level, water regime, deep machine learning

Введение

Совершенствование методов прогнозирования водных ресурсов по-прежнему является одной из важных задач гидрологии, что обусловлено необходимостью надежного планирования водохозяйственной деятельности и своевременного реагирования на возможные бедствия, вызванные наводнениями или засухами.

При работе с устойчивыми гидрологическими режимами использование традиционных методов может быть оправдано, однако их применение ограничено в случае наличия нелинейных зависимостей между исходными характеристиками и сложных паттернов в данных. В последние годы активно развиваются методы глубокого обучения, демонстрирующие перспективные результаты в задачах прогнозирования временных рядов.

В настоящее время физически наиболее обоснованными и широко известными в мире являются следующие математические модели формирования речного стока: модель Сакраменто, учитывающая влажность почвы; комплексная система гидрологического моделирования (HEC-HMS); пространственно-распределенная модель водных ресурсов LisFlood, широко используемая в проекте Европейской Системы Предупреждения о Наводнениях; концептуальная модель HBV, использующая данные об осадках и температуре воздуха [3, 7]. Однако все эти модели используются только для краткосрочных прогнозов водного режима и к долгосрочным прогнозам отношения не имеют. В подавляющем большинстве случаев методы долгосрочных прогнозов основываются на полуэмпирических подходах, связанных с использованием уравнения водного баланса и построением регрессионных зависимостей, которые часто не дают желаемого результата. Более того, все указанные физически обоснованные и эмпирические модели не всегда эффективны при моделировании сложных нелинейных процессов в гидрологических системах [9]. Переход к разработке метода прогноза водного режима с использованием глубокого обучения позволяет в определенной степени сгладить это различие при моделировании сложных нелинейных процессов в гидрологических системах.

В [4] сделана попытка создать методику долгосрочного прогноза максимального уровня воды, используя современные достижения в области глубокого обучения. В то же время полученные результаты не могут считаться полностью законченными, так как они были выполнены на ограниченной по объему выборке исходных данных и без оценки классических, принятых в гидрологической практике критериев эффективности метода

прогноза. Развитие данного подхода предполагало реализацию кросс-валидации для оценки метода прогноза, изменение архитектуры модели, а также подключение дополнительной исходной гидрометеорологической информации в сравнении с предыдущим подходом.

2. Область исследования и данные

2.1 Исследуемые водосборы

Для оценки применимости методик на основе глубокого обучения были выбраны три водпоста р. Исеть (бассейн речной системы р. Тобол), соответствующие предыдущему исследованию [4] (табл. 1). Режим формирования весеннего половодья по указанным водпостам достаточно однородный по своему виду для всей рассматриваемой территории с некоторым преобладанием горного рельефа для водпоста Катайск. Тающие снега являются наиболее важным источником питания поверхностного стока р. Исеть. В то же время вниз по течению возрастает доля дождевого питания. Весеннее половодье начинается в первой половине апреля и заканчивается обычно в середине июня. Основные гидрографические характеристики по всем трем водпостам приведены в табл. 1 согласно справочным данным [2].

Таблица 1. Гидрографические характеристики по р. Исеть
Table 1. Hydrographic characteristics of the Iset River

Название водпоста (индекс)	GPS координаты, градус	Расстояние от истока, км	Площадь водосбора, км ²	Нуль графика водпоста, м
Катайск (12123)	56.28 и 62.58	220	12800	86.55
Шадринск (12125)	56.08 и 63.63	309	23400	72.82
Мехонское (12127)	56.15 и 64.56	451	52300	63.75

2.2. Исходные данные

Список исходных переменных и их начальных превращений приведен в табл. 2.

Таким образом, для имеющихся трех водпостов у нас доступны:

- метеорологические признаки, такие как температура воздуха, температура точки росы, влажность, сумма осадков, средняя скорость ветра, высота снежного покрова;

- гидрологические признаки: уровень воды, расход воды;
- данные по уровням грунтовых вод.

Итого девять исходных признаков.

Таблица 2. Список исходных переменных, полученных из исходных данных, и их преобразование

Table 2. Base features from raw data and the processed parameters

Кодировка	Физический смысл	Расчетная формула	Входной признак
at_N_h	Температура воздуха N часов, °C	-	-
at	Температура воздуха среднесуточная, °C	$\frac{1}{M} \sum_{\text{в течение суток}} at_N_h$	+
asd	Среднесуточная высота снежного покрова, см	-	+
ws_N_h	Средняя скорость ветра в срок наблюдения (каждые h часов), м/с	-	-
awspd	Среднесуточная скорость ветра, м/с	$\frac{1}{M} \sum_{\text{в течение суток}} ws_N_h$	+
dpt_N_h	Температура точки росы в срок наблюдения, °C	-	-
dpt	Среднесуточная температура точки росы, °C	$\frac{1}{M} \sum_{\text{в течение суток}} dpt_N_h$	+
ps_N_h	Сумма осадков за период между сроками h часов, мм	-	-
psbd	Сумма осадков за сутки, мм	$\frac{1}{M} \sum_{\text{в течение суток}} ps_N_h$	+
rhp_N_h	Относительная влажность в срок наблюдения (h часов), %	-	-
rhp	Среднесуточная влажность, от 0.0 до 1.0	$\frac{1}{M \cdot 100} \sum_{\text{в течение суток}} rel_hum_N_h$	+
flow	Среднесуточный расход воды, в м ³ /сек	-	+
level	Среднесуточный уровень воды, см, над нулем графика водпоста	-	+
gw_level*	Уровни грунтовых вод, см	-	+

Примечание. M – количество показаний.

*Значения уровней грунтовых вод использовались в качестве эксперимента для оценки оправдываемости их применимости.

2.3. Подготовка исходных данных

Подготовка каждой группы данных включала:

- 1) приведение данных к единому временному масштабу путем агрегации, учитывая различную частоту исходных измерений;
- 2) интерполяцию для заполнения пропусков и создания непрерывного ряда данных;
- 3) объединение гидрологических и метеорологических признаков.

Для приведения к единому временному масштабу данные агрегировались по дню с последующим усреднением для всех исходных признаков, кроме осадков – показания последних суммировались в течение суток. В качестве интерполяции использовался метод кубической интерполяции, сохраняющий монотонность данных. Для объединения гидро- и метеорологических признаков данные группировались по дню с усреднением характеристик в случае соответствия нескольких метеостанций одному водопосту.

Нельзя не отметить необходимость чистки исходных данных. Анализ используемой выборки выявил наличие аномальных примеров, которые характеризуются несогласованностью между различными показателями, например, между уровнями и накопленными осадками и снежным покровом, что указывает на необходимость расширения набора учитываемых переменных для более полного описания исследуемых процессов. Количество выявленных аномалий не превышало 5 случаев для каждого из трех пунктов, при этом общая длина ряда наблюдений составляла не менее 28 лет для каждого пункта. Подобных аномалий для каждого из трех пунктов набиралось до пяти, тем не менее суммарная выборка составляла не менее 28 лет.

2.4. Разработка признаков

Существенное значение для качества прогноза имеет расширение набора входных переменных путем разработки дополнительных признаков, которые представлены в табл. 3.

Введенными временными признаками послужили тригонометрические разложения временного шага (дня), в то время как накопительными послужили кумулятивные суммы осадков и уровней воды, начинающиеся с 1 июля каждого года.

3. Методология

3.1. Сбор и подготовка данных

Все исходные данные для проведения численных экспериментов были представлены ФГБУ «Уральское УГМС» и ФГБУ «Гидрометцентр России». Описание данных, использовавшихся в этой работе, соответствует описанию, приведенному в [4].

В целях расширения возможностей использования метода глубокого обучения в работе сделана попытка реализовать эту модель с использованием данных об уровне грунтовых вод. Принципиальным моментом в данном случае является тот факт, что погрешность измерения уровня грунтовых вод сравнима только с погрешностью измерения уровня воды на водпостах (± 0.07 м) [1]. Это обстоятельство имеет решающее значение, так как погрешность измерения всех остальных гидрологических характеристик, которые мы наблюдаем (или рассчитываем, как в случае с расходом воды) большая и может достигать 20–25 %.

Таблица 3. Список дополнительно введенных переменных
Table 3. Derived features

Кодировка	Расчетная формула	Входной признак
month	Взятие месяца из текущей даты	–
month_x	$\sin(2 \cdot \pi \cdot \text{month}/12)$	+
month_y	$\cos(2 \cdot \pi \cdot \text{month}/12)$	+
day	Взятие дня из текущей даты с начала текущего года	–
day_x	$\sin(2 \cdot \pi \cdot \text{day}/365) \mid \sin(2 \cdot \pi \cdot \text{day}/366)$, отсчет начинается от 01.07 каждого года	+
day_y	$\cos(2 \cdot \pi \cdot \text{day}/365) \mid \cos(2 \cdot \pi \cdot \text{day}/366)$ отсчет начинается от 01.07 каждого года	+
cumsum_precip	$Sp_t = \sum_{i=1}^t \text{psbd}_i$ <p>где (Sp_t) – кумулятивная сумма осадков на момент времени t, а psbd_i – значение переменной psbd на временном шаге i. Период расчета $i \in [01.07.y, 01.07.(y+1)]$, где y – год начала расчета, дата в формате [день.месяц.год]</p>	+
cumsum_level	$Sl_t = \sum_{i=1}^t \text{level}_i$ <p>где (Sl_t) – кумулятивная сумма уровней воды на момент времени t, а level_i – значение переменной level на временном шаге i. Период расчета $i \in [01.07.y, 01.07.(y+1)]$, где y – год начала расчета, дата в формате [день.месяц.год]</p>	+

Следует отметить, что подавляющая часть данных наблюдений об уровнях грунтовых вод в 80-х годах XX века перешли в ведение сначала Министерства геологии СССР, а позднее в Роснедра. Изменение системы доступа к этим данным наблюдений привело к реальной потере глубокого интереса их использования при разработке современных моделей процессов формирования речного стока для гидрологических прогнозов.

В рамках данной работы по официальному запросу в ФГБУ «Гидро-спецгеология» получена исходная информация по уровням грунтовых вод для пунктов, располагающихся в непосредственной близости от рассматриваемых водпостов р. Исеть (рис. 1).

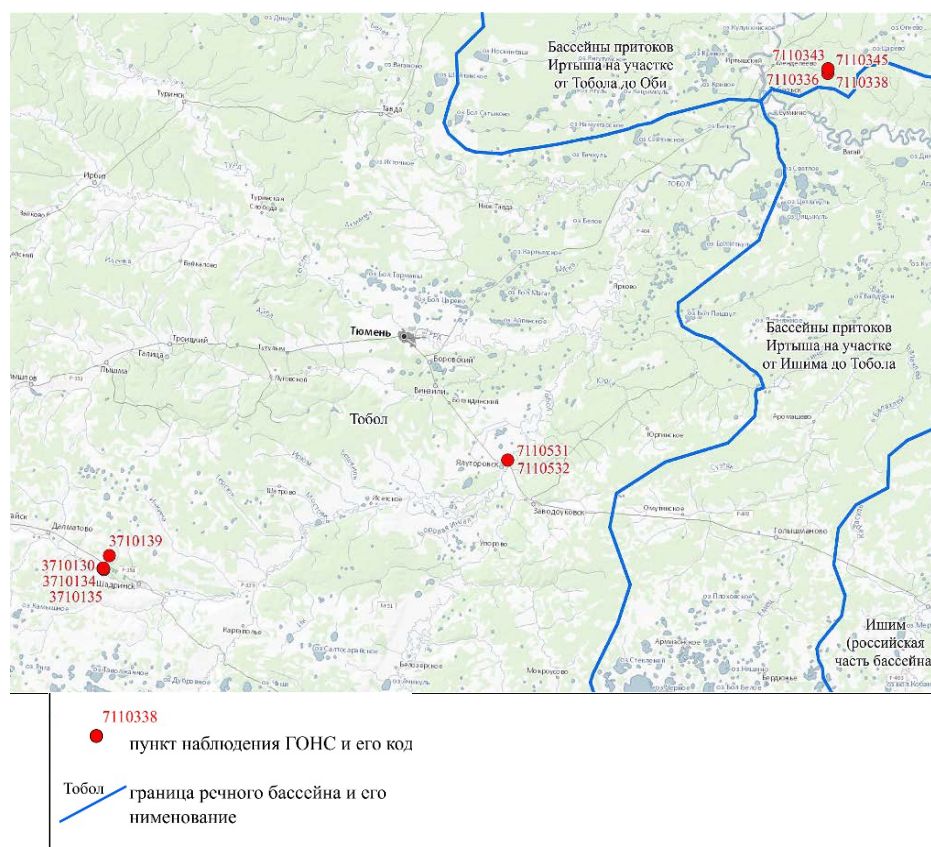


Рис. 1. Схема расположения пунктов государственной наблюдательной сети с естественным и слаборазрушенным режимом подземных вод (масштаб 1:2 000 000).

Fig. 1. Locations of national monitoring sites with natural and quasi-natural groundwater regime (scale 1:2 000 000).

3.2. Архитектура модели глубокого обучения

При проведении исследований в качестве ключевого алгоритма была выбрана модель, реализующая архитектуру N-HiTS [6]. Несмотря на гибкость модели TFT в работе с различной природы входными данными, используемой в предыдущем исследовании на тех же водосборах, методология настоящей работы включает применение блочных структур, базирующихся на многослойных перцептронах (MLP). Так, в модели TFT трансформер задействуется исключительно для агрегации признаков, тогда как их экстракция осуществляется посредством рекуррентных нейронных сетей, а именно с помощью LSTM блоков и блоков, аналогичных MLP. Более того, N-HiTS показывает результаты не хуже, чем архитектуры на основе трансформеров, такие как Autoformer, Informer и т. д., на классических датасетах вроде ETTm2, Weather [6]. В то время как более простое строение по сравнению с моделью TFT может способствовать снижению чувствительности модели к выбору гиперпараметров и улучшению масштабируемости модели.

В архитектуре N-HiTS входные данные проходят через последовательность стеков, где каждый стек специализируется на своем уровне абстракции данных, при этом внутри блока (составляющей стека) происходит постепенное уменьшение размера через слои пулинга

$$x^{(p)} = \text{MaxPool}(x). \quad (3.1)$$

Затем мы получаем скрытое представление через несколько подряд идущих полносвязных слоев вместе с функциями активации, закрепленной за каждым слоем

$$h = \text{MLP}(x^{(p)}), \quad (3.2)$$

которое используется для получения значений параметров для обратного (backcast) θ_b и прямого (forecast) θ_f прогнозов

$$\theta_b = W_b h + b_b \quad (3.3a)$$

$$\theta_f = W_f h + b_f, \quad (3.3b)$$

последующая интерполяция для восстановления исходных размерностей:

$$\hat{x} = \text{interpolate}(\theta_b, L_{input}), \quad (3.4a)$$

$$\hat{y} = \text{interpolate}(\theta_f, L_{output}), \quad (3.4b)$$

где x – тензор входных данных размерности $[batch_size, L_{input}, features_num]$; MLP – связка полносвязных слоев (многослойный перцептрон) вместе со слоями нормализации батча и дропаутом; W_b и b_b – веса и смещение линейного слоя для получения

параметров для backcast (обратного прогноза); W_f и b_f – аналогичные компоненты для получения параметров для forecast (прямого прогноза); \hat{x} – тензор обратного прогноза; \hat{y} – тензор прямого прогноза; *interpolate* – слой интерполяции (использовалась линейная); L_{input} – длина входного временного ряда; L_{output} – длина выходного временного ряда.

В каждом стеке входные данные сначала проходят через один или несколько блоков последовательно. Перед этим инициализируется начальный прогноз, который является тензором, заполненным нулями

$$F_{stack} = 0. \quad (3.5)$$

Каждый блок генерирует обратный прогноз (backcast) и прямой прогноз (forecast). Обратный прогноз вычитается из входных данных, создавая остаток, который передается следующему блоку, а в конечном счете и следующему стеку, позволяя последующим структурным компонентам сосредоточиться на еще необработанных аспектах временного ряда. То есть для каждого блока в стеке имеем

$$\begin{aligned} \text{для } i = 1..B: \{(\hat{x}_i, \hat{y}_i) = \text{Block}_i(x_i), \\ F_{stack} = F_{stack} + \hat{y}_i, \\ x_{i+1} = x_i - \hat{x}_i\}, \end{aligned} \quad (3.6)$$

$$R_{stack} = x_B. \quad (3.7)$$

Прямые прогнозы блоков суммируются в рамках стека, в то время как входные данные для каждого последующего блока внутри этого стека уменьшаются на значение обратного прогноза, а затем все прогнозы стеков складываются для получения финального результата

$$\hat{y} = \sum_{s=1}^S F_{stack}^{(s)}, \quad (3.8)$$

где B – количество блоков в стеке; S – общее количество стеков; F_{stack} – (прямой) прогноз стека; R_{stack} – остаток стека; x_i – тензор входных данных для i -го блока текущего стека; \hat{x}_i – обратный прогноз i -го блока текущего стека; \hat{y}_i – прямой прогноз i -го блока текущего стека.

Благодаря такой архитектуре каждый последующий стек работает с все более очищенными, гранулированными данными, а интерполяция помогает восстановить сигнал после сжатия, которое образуется в результате операций пулинга, обеспечивая эффективную обработку временных рядов на разных масштабах. Данный процесс представлен на рис. 2.

На рис. 3 представлена демонстрация прогноза, полученного с помощью этой модели.




Рис. 2. Упрощенная архитектура используемой модели N-HiTS. Слева изображена структура стека и блока, справа – представление «в общем». Выходы каждого блока становятся входами для каждого последующего блока и итоговым результатом является сумма прямых прогнозов каждого стека.

Fig. 2. Simplified N-HiTS model architecture. Stack and block structure (left) and generalized representation (right) of the model. Block outputs serve as inputs for subsequent blocks, with the final prediction being the sum of direct forecasts from each stack.

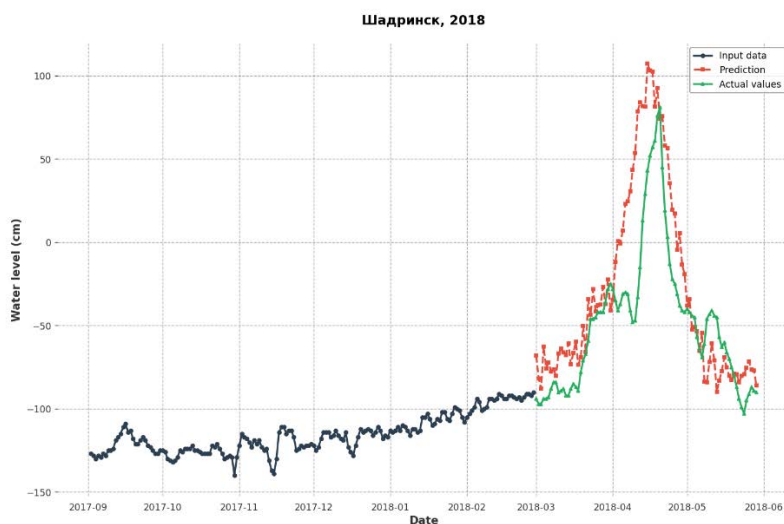


Рис. 3. Пример работы модели: прогноз гидрографа для Шадринска за 2018 год. По осям координат: Date – дата, Water level (cm) – уровень воды (в см). Обозначения: Input data – входные данные, Prediction – предсказанные значения, Actual values – фактические значения.

Fig. 3. Model forecast example for 2018, Shadrinsk case. Axes: Date and Water level (cm). Legend: Input data, Prediction values, and Actual values.

3.3. Выбор гиперпараметров

В табл. 4 представлены параметры конфигурации модели, полученные в результате численных экспериментов, которые показали наилучшую эффективность в рамках текущей задачи.

Таблица 4. Параметры архитектуры используемой модели
Table 4. Model architecture parameters

Наименование	Значение	Описание
stacks_num	4	Количество стеков
blocks_num	2	Количество блоков внутри одного стека
mlp_layers_num	2	Количество полносвязных слоев внутри одного блока
layers_width	352	Размер скрытого пространства
dropout	0.03	Значение дропаута
activation	LeakyReLU	Выбор функции активации
input_len	180	Длина входных временных рядов
output_len	90	Длина выходного временного ряда

Также было экспериментально установлено, что наиболее оптимальной датой начала прогноза является 15 марта каждого года. Дополнительно использовалось линейное уменьшение параметра скорости обучения. Гиперпараметры обучения представлены в табл. 5.

Таблица 5. Гиперпараметры обучения

Table 5. Training hyperparameters

Наименование	Значение	Описание
optim	Adam	Оптимизатор
epochs_num	60	Количество эпох.
loss_function	MSE	Функция потерь. Использовалась MSE
batch_size	256	Размер батча
lr	0.001	Параметр скорости обучения
gamma	0.0005	Финальный множитель начальной скорости обучения lr , к которому сводится значение последней на последней эпохе как $lr_{final} = lr * gamma$
grad_clip	3.5	Граница нормы градиентов
weight_decay	0.000005	Коэффициент L2-регуляризации

4. Проведение экспериментов

4.1. Временные границы

В данном эксперименте использовались временные ряды с 1990 по 2023 год включительно.

4.2. Валидация

В качестве валидационного периода фиксировался временной промежуток с 2018 по 2022 год протяженностью в 5 лет. Используемая метрика оценки описана в разделе 4.4 «Метрики оценки» – формула 4.1.

4.3. Кросс-валидация

Для более справедливой оценки применимости разработанных методов была дополнительно проведена кросс-валидация с окном $window_{size}$, равным 5 годам, и пересечением $intersection$, равным 2 годам. Для каждого эксперимента:

- фиксируется валидационный интервал начиная с y_0 года и до $y_1 = y_0 + window_size$;
- собираются метрики на каждом из подобных интервалов;

• происходит смещение на величину $intersection = 2$ года вправо и повторяется эксперимент.

Так как при таком подходе неизбежно появляются дубликаты из-за наличия пересечения, среди экспериментов для одного и того же года и региона выбирается наилучший результат значения критерия. Процесс кросс-валидации графически представлен на рис. 4.




Рис. 4. Графическое представление кросс-валидации. Эксп. {i} обозначает эксперимент i, где $i = \overline{1, N}$, N – общее количество экспериментов.

Fig.4. Cross-validation scheme. Exp. {i} denotes an experiment i, where $i = \overline{1, N}$ and N is the total number of experiments

4.4. Критерии оценки

В этом исследовании использовались следующие критерии оценки:

1) отношение Δ разницы предсказанного и фактического максимумов к некоторой фиксированной константе, задаваемой для каждого водпоста для валидационного периода;

2) отношение (S/σ) среднеквадратичной погрешности поверочных прогнозов к среднеквадратичной ошибке всего рассматриваемого временного промежутка для проведения кросс-валидации.

В случае оценки на валидации использовалась метрика

$$\Delta_i^j = \frac{abs(\max(y_i^j) - \max(\hat{y}_i^j))}{\Delta_{доп}^j}, \quad (4.1)$$

где j – водпост; i – год; y – временной ряд фактических значений; \hat{y} – временной ряд прогнозных; $\Delta_{доп}^j$ – фиксированная константа для

каждого водпоста j , которая может быть интерпретирована как максимально допустимая абсолютная разница между максимальным прогнозным значением и максимальным фактическим в пределах рассматриваемого горизонта прогноза.

Для оценки оправдываемости использовались следующие отношения:

$\Delta_i^j \in [0, 0.4)$ – отлично;

$\Delta_i^j \in [0.4, 0.7)$ – хорошо;

$\Delta_i^j \in [0.7, 1.0)$ – удовлетворительно;

$\Delta_i^j \in [1.0, +\infty)$ – неудовлетворительно.

В частности, при подсчете оправдываемости на валидационной выборке проверялось неравенство $\Delta_i^j < 1$ для каждой пары («год», «водпост»).

В случае кросс-валидации критерием оценки выступало отношение S/σ , при этом S – средняя квадратичная погрешность поверочных прогнозов, вычисляемая по формуле

$$S = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - 1}}, \quad (4.2)$$

где σ – средняя квадратичная ошибка, посчитанная для n лет; y_i, \hat{y}_i – соответствующие значения реальных и предсказанных значений. Сама интерпретация достаточно тривиальна: разброс прогнозов самого метода не должен приближаться к среднеквадратичной, иначе его применение нецелесообразно. Считается, что применение методики целесообразно, если S/σ не более 0.80 [5].

5. Обсуждение и результаты

5.1. Валидация

В данном исследовании проводилась оценка метода прогноза с заблаговременностью в 90 суток. Результаты оправдываемости по сравнению с ранее использованным методом предоставлены на рис. 5.

Анализ результатов показывает, что модель N-HiTS достигает уровня точности не ниже, чем лучшие показатели из предыдущих конфигураций TFT для обоих горизонтов прогнозирования. Примечательно, что ранее для разных водпостов оптимальная заблаговременность различалась. В частности, для Китайска была оптимальна модель с заблаговременностью 60 суток, в то время как для Мехонского – 90 суток. Предложенный способ демонстрирует результаты лучшие, чем любой из ранее используемых подходов при максимальной заблаговременности для всех исследуемых водпостов.




Рис. 5. Сравнение оправдываемости прогнозов моделей N-HITS (заблаговременность 90 суток, синий) и TFT (заблаговременности 60 и 90 суток, зеленый и желтый соответственно) по критерию Δ для валидационного периода. По оси ординат – доля прогнозов с соотношением (4.1) менее 1, по оси абсцисс – водпосты. Более высокие значения соответствуют лучшей оправдываемости. N-HITS демонстрирует наилучшие результаты для всех случаев.

Fig. 5. Model performance comparison between N-HITS (90-day lead time, blue) and TFT (60 and 90-day lead times, green and yellow respectively) using Δ criterion for validation period. Y-axis: proportion of successful forecasts (ratio (4.1) < 1); X-axis: gauging stations. Higher values indicate better performance, with N-HITS showing superior results for all cases.

5.2. Кросс-валидация

Для кросс-валидации была выбрана модель, обеспечивающая наибольшую эффективность – N-HITS с горизонтом прогноза в 90 суток. В результате кросс-валидации для каждого года в выборке имеем значения максимального фактического и максимального предсказанного уровней в пределах рассматриваемого горизонта прогноза, которое можно представить в виде временного ряда, как показано на рис. 6.

Усредненные результаты по каждому отношению S/σ приведены на рис. 7.

5.3. Влияние использования данных грунтовых вод

Несмотря на наличие исследований о предсказании непосредственно самих уровней грунтовых вод [8], в работе выполнен анализ учета данных на подземных скважинах в рамках разработанного метода прогноза максимального уровня воды. Результаты расчетов показывают, что использование таких данных наблюдений позволяет снизить отношение S/σ для кросс-валидации по водпосту Шадринск на 0.2 (рис. 8), что существенно улучшает качество разработанного метода прогноза.



Рис. 6. Сопоставление фактического и предсказанного максимальных уровней на примере Шадринска, “real” – фактический, “pred” – предсказанный. Рассматриваемый горизонт прогноза составляет 90 временных шагов (суток) и отсчитывается с 15 марта каждого года, внутри которого выбираются максимумы среди фактических и предсказанных значений. По оси абсцисс – рассматриваемый год, по оси ординат – уровень воды (в см.)

Fig. 6. Comparison of observed and predicted water level values for Shadrinsk ('real' and 'pred' respectively). Forecast horizon is 90 timesteps (days) starting from March 15 each year, with maxima selected from both observed and predicted values within this period. X-axis: year; Y-axis: maximum water level (cm)

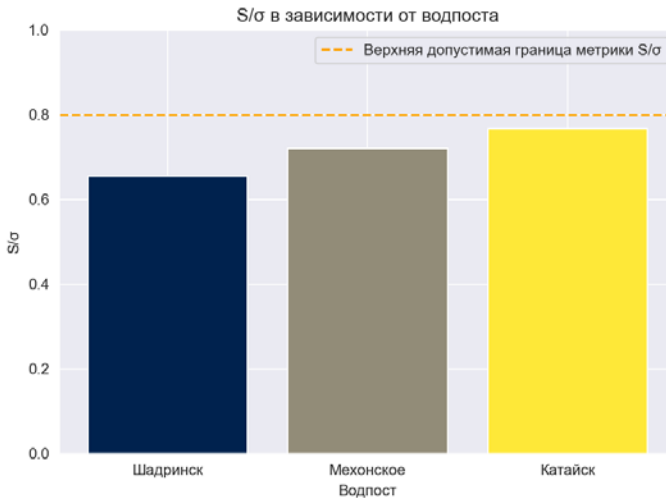


Рис. 7. Значения отношения S/σ для кросс-валидации. Чем ниже, тем лучше. Результаты на каждом из исследуемых водосборов удовлетворяет критерию эффективности применения методики.

Fig. 7. Cross-validation S/σ ratio values. Lower values indicate better performance. Results for all studied catchments meet the forecast verification criteria.




Рис. 8. Значения отношения S/σ для кросс-валидации с использованием данных уровней грунтовых вод. В случае Шадринска получается понижение метрики на 30 %. В остальных случаях статистически значимого эффекта обнаружено не было.

Fig. 8. Cross-validation S/σ ratio values using groundwater level data. For Shadrinsk, the metric decreased by 30 %. No statistically significant effect was observed in other cases.

Использование данных по уровням грунтовых вод показало улучшение в 1/3 случаев. Для более глубокого анализа влияния использования данных наблюдений за уровнем грунтовых вод необходимо существенно расширить это исследование по большему числу водных объектов.

5.4. Перспективы применения и ограничения метода

Разработанный метод демонстрирует значительный потенциал, позволяя моделировать временной ряд длиной в 90 суток, а относительная гибкость архитектуры позволяет адаптировать модель под различные временные признаки и временные масштабы. Добавление новых источников данных, как, например, в случае с уровнями грунтовых вод, способно улучшить показатели эффективности, при этом не требуется существенных изменений модели.

Необходимо отметить, что при реализации данного метода нужно учитывать определенные ограничения по исходным данным. Прежде всего это: 1) требования к качеству входных данных и 2) определенные трудности с использованием данного подхода при реализации валидации. В то же

время указанные ограничения носят достаточно общий характер практически во всех численных методах, использующих гидрометеорологические данные наблюдений.

Заключение

В результате выполненного исследования была проведена комплексная оценка разработанного метода долгосрочного прогноза максимального уровня воды с использованием глубокого обучения на примере нескольких водпостов р. Исеть. Была проведена оценка перехода на новую архитектуру N-NiTS, которая позволила увеличить оправдываемость на валидационной выборке по сравнению с архитектурой TFT. Результаты работы показали, что метод удовлетворяет критерию S/σ при валидации на независимых выборках посредством кросс-валидации. В ходе валидации новая модель показала существенное улучшение оправдываемости прогнозов по сравнению с предшествующим аналогом на всех анализируемых водпостах.

Дополнительно в рамках данной работы была проведена оценка эффективности использования данных грунтовых вод для долгосрочного прогноза максимального уровня воды. Анализ результатов демонстрирует положительную динамику в одной трети случаев, что может быть вызвано недостаточным количеством водных объектов. Данное обстоятельство указывает на необходимость дальнейшего исследования и расширения количества анализируемых водосборов для повышения статистической значимости результатов.

Учитывая результаты настоящей работы, можно утверждать, что применение методов глубокого обучения в задаче прогноза уровней воды имеет значительные перспективы. Дальнейшие исследования целесообразно направить на расширение исследуемых водосборов, а также применение методов глубокого обучения для разработки методов прогнозов водного режима различной заблаговременности (краткосрочные и среднесрочные).

Авторы выражают благодарность сотрудникам кафедры Прикладной математики № 31 НИЯУ МИФИ за ценные замечания при рассмотрении данной работы на семинаре кафедры 23 сентября 2024 года.

Список литературы

1. Постановление Правительства РФ от 16 ноября 2020 г. №1847 "Об утверждении перечня измерений, относящихся к сфере государственного регулирования обеспечения единства измерений" (пункт 9.25).
2. Ресурсы поверхностных вод СССР: Гидрологическая изученность. Т. 11. Средний Урал и Приуралье. Вып. 2. Тобол / под ред. В.В. Николаенко. Л.: Гидрометеоиздат, 1965. 214 с.
3. Романов А.В. Дорожная карта современных гидрологических прогнозов водного режим // Метеорология и гидрология. 2023. № 12. С. 12-26.

4. Романов А.В., Акмаев Э.Р., Червоненкис М.А. Глубокие нейронные сети архитектуры трансформер в задачах гидрологических прогнозов // Гидрометеорологические исследования и прогнозы. 2023. № 2 (388). С. 138-155.
5. Бэфани Н.Ф., Калинин Г.П. Упражнения и методические разработки по гидрологическим прогнозам. Л.: Гидрометеоиздат, 1983. С. 390.
6. Challu C. et al. Nhits: Neural hierarchical interpolation for time series forecasting // Proceedings of the AAAI conference on artificial intelligence. 2023. Vol. 37, no. 6. P. 6989-6997.
7. Devia G.K., Ganasri B.P., Dwarakish G.S. A REVIEW ON HYDROLOGICAL MODELS // Aquatic Procedia. 2015. Vol. 4. P. 1001-1007. <http://dx.doi.org/10.1016/j.aqpro.2015.02.126>
8. Khan J. et al. A comprehensive review of conventional, machine learning, and deep learning models for groundwater level (GWL) forecasting // Applied Sciences. 2023. Vol. 13, no. 4. P. 2743.
9. Kratzert F. et al. Toward improved predictions in ungauged basins: Exploiting the power of machine learning // Water Resources Research. 2019. Vol. 55, no. 12. P. 11344-11354.

References

1. Postanovlenie Pravitel'stva RF ot 16 noyabrya 2020 g. №1847 "Ob utverzhdenii perechnya izmereniy, odnosyashchihsiya k sfere gosudarstvennogo regulirovaniya obespecheniya edinstva izmereniy" (punkt 9.25) [in Russ.].
2. Resursy poverhnostnyh vod SSSR: Gidrologicheskaya izuchennost'. T. 11. Sredniy Ural i Priural'e. Vyp. 2. Tobol / pod red. V.V. Nikolaenko. Leningrad, Gidrometeoizdat publ., 1965, 214 p. [in Russ.].
3. Romanov A.V. A Roadmap of Modern Hydrological Forecasts of Water Regime. *Meteorologiya i Gidrologiya* [Russ. *Meteorol. Hydrol.*], 2023, no. 12, pp. 12-26 [in Russ.].
4. Romanov A.V., Akmaev E.R., Chervonenkis M.A. Deep neural networks of transformer architecture in problems of hydrological forecasts. *Gidrometeorologicheskie issledovaniya i prognozy* [*Hydrometeorological Research and Forecasting*], 2023, vol. 388, no. 2, pp. 138-155 [in Russ.].
5. Бэфани Н.Ф., Калинин Г.П. Упражнения и методические разработки по гидрологическим прогнозам. Лeningrad, Gidrometeoizdat publ., 1983, 390 p. [in Russ.].
6. Challu C. et al. Nhits: Neural hierarchical interpolation for time series forecasting. Proceedings of the AAAI conference on artificial intelligence. 2023, vol. 37, no. 6, pp. 6989-6997.
7. Devia G.K., Ganasri B.P., Dwarakish G.S. A review on hydrological models. *Aquatic Procedia*, 2015, vol. 4, pp. 1001-1007. DOI: 10.1016/j.aqpro.2015.02.126.
8. Khan J. et al. A comprehensive review of conventional, machine learning, and deep learning models for groundwater level (GWL) forecasting. *Applied Sciences*, 2023, vol. 13, no. 4, pp. 2743.
9. Kratzert F. et al. Toward improved predictions in ungauged basins: Exploiting the power of machine learning. *Water Resources Research*, 2019, vol. 55, no. 12, pp. 11344-11354.

Поступила 06.11.2024; одобрена после рецензирования 02.12.2024;
принята в печать 10.10.2024.

Submitted 06.11.2024; approved after reviewing 02.12.2024;
accepted for publication 10.10.2024.